多源信息融合下冷链配送车辆碳排放动态预测方法

杨 霖[1,4], 刘双印[1,3], 徐龙琴[1,2], 赫 敏[1,3], 绳庆峰[1,3], 韩佳伟[4*]

(1. 仲恺农业工程学院 信息科学与技术学院,广东广州 510225,中国; 2. 仲恺农业工程学院广州市农产品质量安全溯源信息技术重点实验室,广东广州 510225,中国; 3. 仲恺农业工程学院智慧农业创新研究院,广东广州 510225,中国; 4. 北京市农林科学院信息技术研究中心,北京 100097,中国)

摘 要: [**目的/意义**]冷链配送碳排放动态预测是企业碳排放精准评估及其绿色信用等级评定的重要依据。本研究面向车辆碳排放受路况信息、行驶特征、制冷参数等多因素影响，提出一种融合多源信息的冷藏车辆碳排放动态预测模型。[**方法**]基于道路车辆数量与像素面积占比表征路况信息，构建基于改进YOLOv8s的路况信息识别模型，并以路况信息、行驶特征（速度、加速度）、货物重量、制冷参数（温度、功率）等为输入，构建基于改进iTransformer的冷藏车辆碳排放动态预测模型。最后与其他模型展开对比分析，分别验证路况信息识别与车辆碳排放动态预测的精度。[**结果**]改进的YOLOv8s路况信息识别模型在精确率、召回率和平均识别精度上分别达到98.1%、95.5%和98.4%，比YOLOv8s分别提高了1.2%、3.7%和0.2%，参数量和运算量分别减少了12.5%和31.4%，检测速度提高了5.4%。改进的iTransformer模型碳排放量预测的均方误差、平均绝对误差、均方根误差和R^2分别为0.026 1 %VOL、0.079 1 %VOL、0.161 5 %VOL和0.940 0，均优于其他时序预测模型。[**结论**]提出的多源信息融合下冷链配送碳排放预测模型可实现对冷藏车辆碳排放量的精准预测，为有效降低冷链配送碳排放与提升配送企业绿色信用等级等提供理论参考。

关键词: 冷链配送；碳排放；路况识别；时序预测；YOLOv8s；iTransformer；多源信息融合；渐进特征金字塔网络

中图分类号: S24 **文献标志码:** A **文章编号:** SA202403020

引用格式:杨霖, 刘双印, 徐龙琴, 赫敏, 绳庆峰, 韩佳伟. 多源信息融合下冷链配送车辆碳排放动态预测方法[J]. 智慧农业(中英文), 2024, 6(4): 138-148. DOI：10.12133/j.smartag.SA202403020

YANG Lin, LIU Shuangyin, XU Longqin, HE Min, SHENG Qingfeng, HAN Jiawei. Dynamic Prediction Method for Carbon Emissions of Cold Chain Distribution Vehicle under Multi-Source Information Fusion[J]. Smart Agriculture, 2024, 6(4): 138-148. DOI：10.12133/j.smartag.SA202403020 (in Chinese with English abstract)

0 引 言

随着“双碳”目标的提出，加速农产品冷链绿色低碳发展已成为行业共识与必然选择[1]。作为低温维持与行驶动力双向能源需求的冷链配送环节，更需要加快减排降耗和低碳转型步伐，以有效应对冷链规模持续扩张与碳排放控制的突出矛盾[2,3]。冷链配送碳排放精准感知是合理制定碳减排策略与绿色管理效能评价的重要依据，对加快冷链配送甚至整个冷链物流绿色可持续发展具有重要意义，已成为近年来相关学者主要研究热点之一[4,5]。

Jaikumar等[6]以车速、加速度、车辆比功率和发动机转速等作为模型输入，构建了基于人工神经网络的车辆排放预测模型，试验结果显示模型预测值与实际测量值一致性指数达到0.9，预测结果与真实值较为吻合。Seo等[7]也基于人工神经网络，以车速、发动机转速、发动机负荷等车辆行驶特征参数为输入，构建了车辆CO_2排放预测模型，预测误差小于1%。Rivera-Campoverde等[8]考虑车速、加速度和发动机转速等车辆行驶特征参数，基于人

收稿日期：2024-03-15

基金项目：国家自然科学基金项目（62373390，61871475）；国家重点研发计划项目（2022YFD2001804，2023YFD2001302）；北京市农林科学院科研创新平台建设项目（PT2024-24）

作者简介：杨 霖，研究方向为智慧供应链关键技术。E-mail：yanglinear@163.com

*通信作者：韩佳伟，博士，高级农艺师，研究方向为智慧冷链物流关键技术。E-mail：hanjw@nercita.org.cn

copyright©2024 by the authors

工神经网络构建了车辆CO_2和NOx等污染物预测模型，并结合碳排放实测数据验证了两者预测精度均达到98%。李昌庆和谢小平[9]以速度、加速度和比功率等为神经网络输入，构建了车辆尾气CO_2、CO和NOx排放量的预测模型，三种气体预测相对误差均低于3.8%。上述相关研究主要针对普通车辆，且仅考虑车辆行驶特征参数，而冷藏配送车辆碳排放除受行驶特征参数影响之外，也受制冷参数、货物重量等因素影响[10]。此外，Akintomide等[11]也表明车辆碳排放量与拥堵状况呈显著正相关性[12]，拥堵状态下车辆产生的碳排放量为非拥堵的5至9倍。据本课题组深入研究表明，目前仍严重缺乏多源信息融合下冷藏配送车辆碳排放动态预测模型，尚未充分揭示路况条件、行驶特征、制冷参数等对车辆碳排放的综合影响机制[13, 14]，该方面研究可为提升冷链配送碳排放预测精度、合理制定碳减排策略及促进低碳冷链配送发展等提供理论基础与依据。

综上，本研究以冷藏配送车辆为研究对象，综合考虑车辆运行参数、制冷参数、货物重量和路况信息等多源信息，构建冷藏车辆碳排放动态预测模型，实现对冷藏车配送过程中尾气碳排放进行动态测算。首先，构建基于改进YOLOv8s的路况信息识别模型，准确提取道路不同类型车辆数量与像素面积占比。其次，以车辆行驶速度、加速度、货物重量、制冷温度、制冷机功率和路况信息等为输入，构建基于改进iTrasnformer算法的冷藏车辆碳排放动态预测模型。最后，与其他模型进行对比分析，分别验证基于改进YOLOv8s的路况信息识别模型与基于改进iTransformer的碳排放预测模型的性能。

1　数据采集与处理

1.1 数据采集方法

选用车厢长度7.6 m×2.4 m×2.4 m的冷藏车为实验对象，在北京市某主干路上，分别进行正常行驶与制冷两种工况下视频数据采集，车辆行驶里程总共为2 973 km。为确保路况视频视角全方面覆盖道路行驶车辆，视频采集设备安装于车头挡风玻璃的中心位置（图1a）。视频采集设备采用360品牌G300型号行车记录仪，其参数为：单目镜像素200万，分辨率1 080 P，视频帧率30帧/s。车辆尾气CO_2监测设备选用贝斯安智能CO_2在线检测仪（图1b），其参数为：量程0～50 %VOL，精度±0.5 %VOL，云端上传频率1次/s。通过车辆行驶记录仪记载冷藏配送车辆每秒的行驶速度与加速度，使用温湿度传感器采集冷藏车厢内的温度，通过控制单元记录冷藏车制冷机组功率。


a. 路况视频采集方式


b. 车辆尾气CO_2采集方式

图1　路况视频与车辆CO_2数据采集方式

Fig. 1 Data acquisition method of road condition video and vehicle CO_2 exhaust

1.2 车辆图像数据处理

路况视频数据时长共选取1 264 min，分成V_1和V_2两个数据集。其中V_1时长有712 min，从中随机截取不同场景和时刻下的4 238张图片，用于训练路况信息提取模型，按照8∶1∶1的比例随机划分成训练集、验证集和测试集，部分样本如图2所示。然后从剩余的552 min视频数据集V_2中每秒随机截取一帧图像，用于提取路况信息（轿车、公交车、货车数量以及各类车辆的像素面积占比），作为冷藏车碳排放预测模型的路况信息特征。

1.3 车辆碳排放数据处理

由于CO_2在线检测仪在采集或者无线传输时出现数据丢包，在V_2对应时刻下的CO_2碳数据仅回传了32 048条，其中1 072条数据缺失，通过均值插值算法对缺失数据进行补全，将数据缺失值所在位置前后十个数据的均值补充给缺失值，计算如公式（1）所示。



图 2 车载视角下路况图像集样本

Fig.2 Sample road condition image set from vehicle viewpoint

$$\widetilde{Z}_i = \frac{1}{10}\sum_{j=i-5}^{i+5} Z_j (j \neq i) \quad (1)$$

式中：$\widetilde{Z}_i$为第i个缺失值；Z_j为缺失值第j个位置上的数据。

异常数据处理完成后，总共有33 120条碳排放数据。将每条碳排放数据接收时刻下冷藏车辆的行驶速度、加速度、货物质量、制冷温度、制冷机功率和路况信息作为输入，碳排放量为输出构建碳排放时序数据集，划分成80%的训练集、10%的验证集和10%的测试集。

2 算法模型构建

2.1 路况信息识别模型

2.1.1 YOLOv8s

YOLOv8s是当前YOLO系列中的新模型，在YOLOv5模型和YOLOv7基础上进行了改进，目标检测性能最为突出。YOLOv8s模型主要由主干网络、颈部结构和检测头组成。主干网络由CBS（Convolution Batch SiLU）、C2f（CSPDarknet53 to 2-stage FPN）和SPPF（Spatial Pyramid Pooling Fast）结构组成。CBS通过普通卷积、批归一化和SiLU激活函数构成，用于提取局部空间特征。C2f将高级特征与上下文语义信息结合，丰富模型的梯度流[15]。SPPF通过池化操作将不同尺度的局部特征和全局空间特征进行融合，增强模型对目标特征提取能力[16]。颈部结构用于对从主干网络中提取到的特征进行融合，由特征金字塔和路径聚合网络组成，通过自顶向下和自下而上跨层次连接方式确保特征充分融合[17]。检测头使用解耦头和无锚框结构，通过三种尺度的特征图进行目标的分类和位置信息的确认[18]。

2.1.2 全维度动态卷积

YOLOv8s使用普通二维卷积生成特征，滤波器的卷积核不会因输入的不同而改变，若要获取不同的特征，需要增加滤波器的数量，这样会降低模型运算效率。为解决这个问题，使用全维度动态卷积（Omni-Dimensional Dynamic Convolution, ODConv）[19]替换C2f模块中Bottleneck的常规卷积。ODConv通过并行策略引入多维注意力机制，学习四种互补注意力。在空间维度、输入维度、输出维度和卷积核进行不同维度的特征学习，使模型学习到不同维度的差异性，充分捕获上下文关键信息，提高特征提取能力。ODConv在处理过程中首先将特征经全局平均池化输入到全连接和线性整流函数（Rectified Linear Unit, ReLU）激活函数中，然后通过全连接和Sigmoid激活函数产生四种权重，最终由滤波器加权和组成输出特征。ODConv可以在不增加网络宽度和深度情况下得到更准确的识别模型[20]。将改进后的瓶颈层（Bottleneck）定义为Bottleneck-ODC，改进后的C2f模块定义为C2f-ODC，其结构分别见图3和图4。

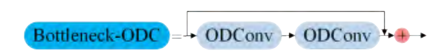


图 3 Bottleneck-ODC结构

Fig. 3 Structure of Bottleneck-ODC

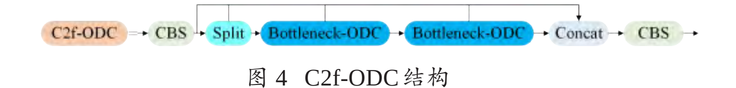


图 4 C2f-ODC结构

Fig. 4 Structure of C2f-ODC

2.1.3 渐近特征金字塔网络

由于道路图像背景复杂，且存在许多噪声，YOLOv8s模型在高层特征与低层特征交互过程中，易使高层特征的语义信息和低层的详细信息丢失，削弱了非相邻尺度的特征融合效果。因此，引入渐近特征金字塔网络（Asymptotic Feature Pyramid Network, AFPN）[21]，使模型在特征提取过程中首先融合低层特征，然后逐渐融入高层特征。由于不同尺度间直接交互，缩小非相邻尺度间的语义差距，充分融合高层语义信息与低层详细信息，避免多级传输中关键信息的丢失。

AFPN在多级特征融合过程中，利用自适应空间特征融合（Adaptively Spatial Feature Fusion, ASFF）[22]为不同层级特征分配各自的空间权重，增强对关键特征的关注力。令$\boldsymbol{X}_{i,j}^{m->n}$表示为从第$m$层到第$n$层的（$i$，$j$）位置的特征向量，将通过特征向

量 $X_{i,j}^{1->n}$，$X_{i,j}^{2->n}$ 和 $X_{i,j}^{3->n}$ 线性组合获得的结果特征向量表示为 $Y_{i,j}^{n}$，如公式（2）。

$$Y_{i,j}^{L} = a_{i,j}^{n} \cdot X_{i,j}^{1->n} + b_{i,j}^{n} \cdot X_{i,j}^{2->n} + c_{i,j}^{n} X_{i,j}^{3->n} \quad (2)$$

式中：$a_{i,j}^{n}$、$b_{i,j}^{n}$ 和 $c_{i,j}^{n}$ 分别表示3个级别特征在第 n 层特征的空间权重，且 $a_{i,j}^{n} + b_{i,j}^{n} + c_{i,j}^{n} = 1$。

2.1.4　YOLOv8s-OA

改进后的模型命名为YOLOv8s-OA，结构如图5所示，在主干网络中引入全维动态卷积模型以生成更多特征，增强主干网络的特征提取能力。在颈部结构中引入渐进特征金字塔网络以保留多级特征融合过程中的重要特征信息，在非相邻层次上直接作用进行特征融合，避免交互过程中特征信息的丢失，提升特征融合效率。

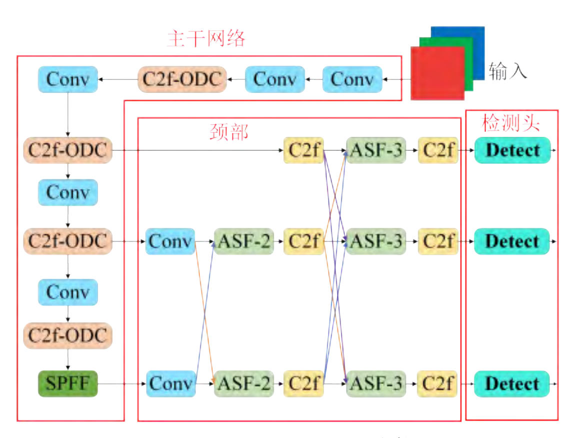


图 5　YOLOv8s-OA 结构

Fig. 5　Structure of YOLOv8s-OA

本研究中路况信息提取过程：通过YOLOv8s-OA识别出道路上的车辆，统计每类车辆数量，同时根据车辆检测框计算各种类型车辆像素面积占比，计算如公式（3）所示。

$$S_i = \sum_{j=1}^{n} (W_{ij} \cdot H_{ij}) / Z \quad (3)$$

式中：i 为车辆类别，如轿车、公交车或货车；n 为图像中 i 类车辆的数量，辆；Z 为图像的像素面积，pixel；W_{ij} 为图像中车辆类型为 i 的第 j 车辆检测框的水平像素；H_{ij} 为图像中车辆类型为 i 的第 j 车辆检测框的垂直像素；S_i 为图像中 i 类车辆的像素面积占比。

2.2 碳排放预测模型

2.2.1　iTransformer

Liu等[23]提出一种倒置新思路，将同一个变量的整条时间序列数据映射成高纬度特征表示，以变量为描述主体独立反映其历史变化过程。通过注意力模块对变量间的相关性进行建模，使用前馈网络在时间维度上逐层对历史特征进行编码，将学习到的特征映射到未来的预测结果中。保留了变量原本的独立性，拓宽模型的感受野，在长期序列预测中表现更为优异。

iTransformer仅使用解码器结构，包括嵌入层（Embedding），投影层（Projector）和可堆叠的Transformer模块（TrmBlock）。特征嵌入层对每个变量历史观测序列独立地进行特征映射，以获得不同的特征表示。自注意力层对不同变量间的相关性进行建模[24]。归一化层使所有变量的特征通道均处于相对统一的分布，减少由变量取值范围的不同而造成的差异性[25]。前馈网络提取历史观测和未来预测中共享的时间特征，将特征外推为预测结果。

2.2.2　外部注意力机制

iTransformer中自注意力层通过所有位置的成对亲和力计算特征加权来更新每个位置上的特征，以捕获单个样本中的长期依赖。然而，自注意力机制具有二次计算复杂度，且忽略了不同样本间的潜在相关性。Guo等[26]提出了一种外部注意力机制（External Attention, EA），通过线性层和归一化层来实现，具有线性复杂性，同时考虑所有数据样本之间的隐含相关性，可有效取代自注意力机制。首先计算查询向量与键向量之间的亲合度，得到注意力特征图，然后经过归一化，最后与值向量相乘得到更加精细的特征图。

2.2.3　iTransformer-EA

改进后的碳排放预测模型定义为iTransformer-EA，结构如图6所示。利用外部注意力机制自注意力模块，减少模型计算的复杂度，学习不同样本间潜在相关性。优化iTransformer特征提取能力，学习出冷藏车辆碳排放数据集中最有辨别度的特征，捕获出有价值的依赖关系，实现对碳排放的精准预测。

2.3 相关性分析

采用皮尔逊相关系数（Pearson Correlation Coefficient, ρ）对比分析冷藏车辆碳排放与不同影响因子之间的相关性，验证模型输入参数选取的必要性与关键性，其计算如公式（4）所示：

$$\rho_{p,q} = \frac{\operatorname{cov}(p,q)}{\sigma_p \sigma_q} = \frac{E(pq) - E(p)E(q)}{\sqrt{E(p^2) - E^2(p)}\sqrt{E(q^2) - E^2(q)}} \quad (4)$$

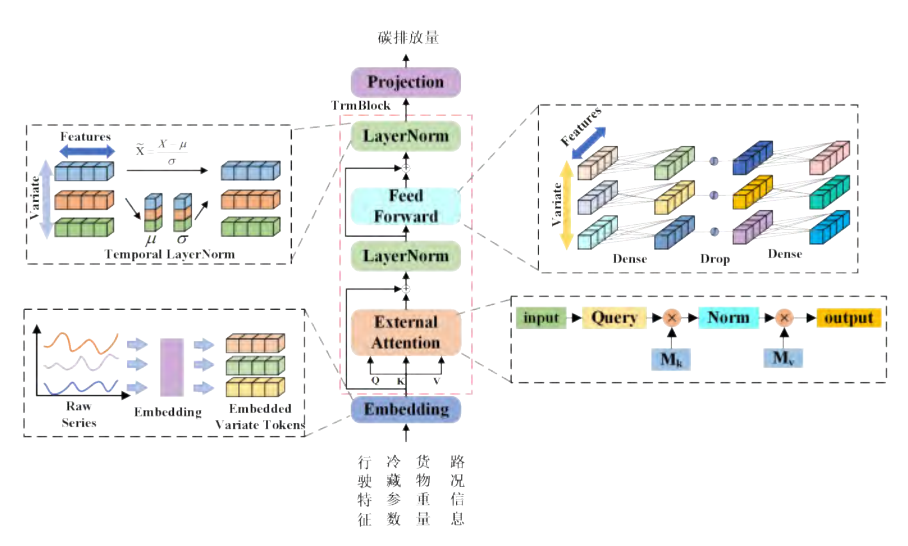


图 6 iTransformer-EA 结构

Fig. 6 iTransformer-EA structure

式中：cov（p，q）为碳排放影响因素 p 和 q 的协方差；σ_p 和 σ_q 分别是 p 和 q 的标准差；E（p）和 E（q）分别是 p 和 q 的期望。ρ 取值范围为［−1，1］，越接近0则认为两个影响因素间无相关性，越接近1表示两者具有强正相关性，越接近−1表示两者负相关性越强。

2.4 实验环境和参数

本研究采用的硬件设备包括Intel（R） Xeon（R） CPU E5-2650 v4 @ 2.20 GHz处理器，运行内存为128 GB，显卡为NVIDIA TESLA K80，显存为12 GB。软件平台为Linux 3.10.0操作系统，Python 3.8.16和Pytorch 2.0.1。YOLOv8s-OA训练输入图像像素大小调整为640×640，训练epochs设置为100次，批处理大小为16，使用预训练的权重文件进行迁移学习，学习率设置为0.001，使用AdamW优化器进行权重优化。iTransformer-EA算法中TrmBlock数量为4，编码层中特征维度设置为512，前馈神经网络层中dropout设置为0.3，训练学习率为0.001，使用Adam优化器，训练epochs为200次。

2.5 性能评价指标

为评估YOLOv8s-OA模型识别性能，选择精确率（P）、召回率（R）、平均精度均值（mean Average Precision, mAP）、检测速度（Frames Per Second, FPS）、模型参数量和运算量作为评价指标。精确率衡量模型在检测为正样本中真正是正样本的正确率，召回率表示模型检测为正样本占所有正样本的比例，平均识别精度综合考虑了模型在不同类别上的检测性能，这三种评价指标的数值越高表明模型的检测性能越优异。参数量是指模型需要训练的参数总量，运算量衡量模型复杂度。选用均方误差（Mean Square Error, MSE）、平均绝对误差（Mean Absolute Error, MAE）、均方根误差（Root Mean Square Error, RMSE）和决定系数（R^2）作为iTransformer-EA碳排放预测的评价指标。MSE、MAE、RMSE和 R^2 通过计算碳排放真实值和模型预测值之间的差异衡量出模型的预测性能，MSE、MAE和RMSE数值越小表示模型预测越接近真实值，模型的预测能力越优，而 R^2 越大表明碳排放预测模型拟合效果越好，各性能评价指标计算公式分别见文献［27］和［28］。

3 结果与分析

3.1 车辆碳排放影响因子的相关性分析

表1给出了车辆碳排放与其影响因子之间的皮尔逊相关系数，其中车辆行驶参数的平均每相关性系数最高（0.841），其次为货物重量（0.807）、路况信息（0.706）和制冷参数（0.682）。相比制冷参数、货物重量和路况信息，车辆行驶参数是影响车辆碳排放强度的主要因素。相比车辆制冷参数，路况信息与车辆碳排放之间具有更强的相关性。而制冷参数与车辆碳排放影响因子的相关性均处于0.67以上，为进一步确保车辆碳排放预测模型的准确性，本研究将其也选为碳排放预测模型输入参数。

3.2 不同路况信息识别模型性能比较

为验证YOLOv8s-OA的路况信息识别的有效性，选择YOLOv8s、YOLOv7-X、YOLOv5s、

表 1　车辆碳排放与其影响因子之间的皮尔逊相关系数

Table 1 Pearson correlation coefficient between vehicle carbon emissions and their impact factors

影响参数	表征因子	相关系数	平均相关系数
行驶	速度	0.869	0.841
	加速度	0.813	
制冷	制冷温度	0.672	0.682
	制冷功率	0.691	
货物	货物重量	0.807	0.807
路况	车辆数量	0.726	0.706
	像素面积占比	0.685	

表 2　不同深度学习算法对路况信息识别性能结果

Table 2 Recognition results of road condition information by different deep learning algorithms

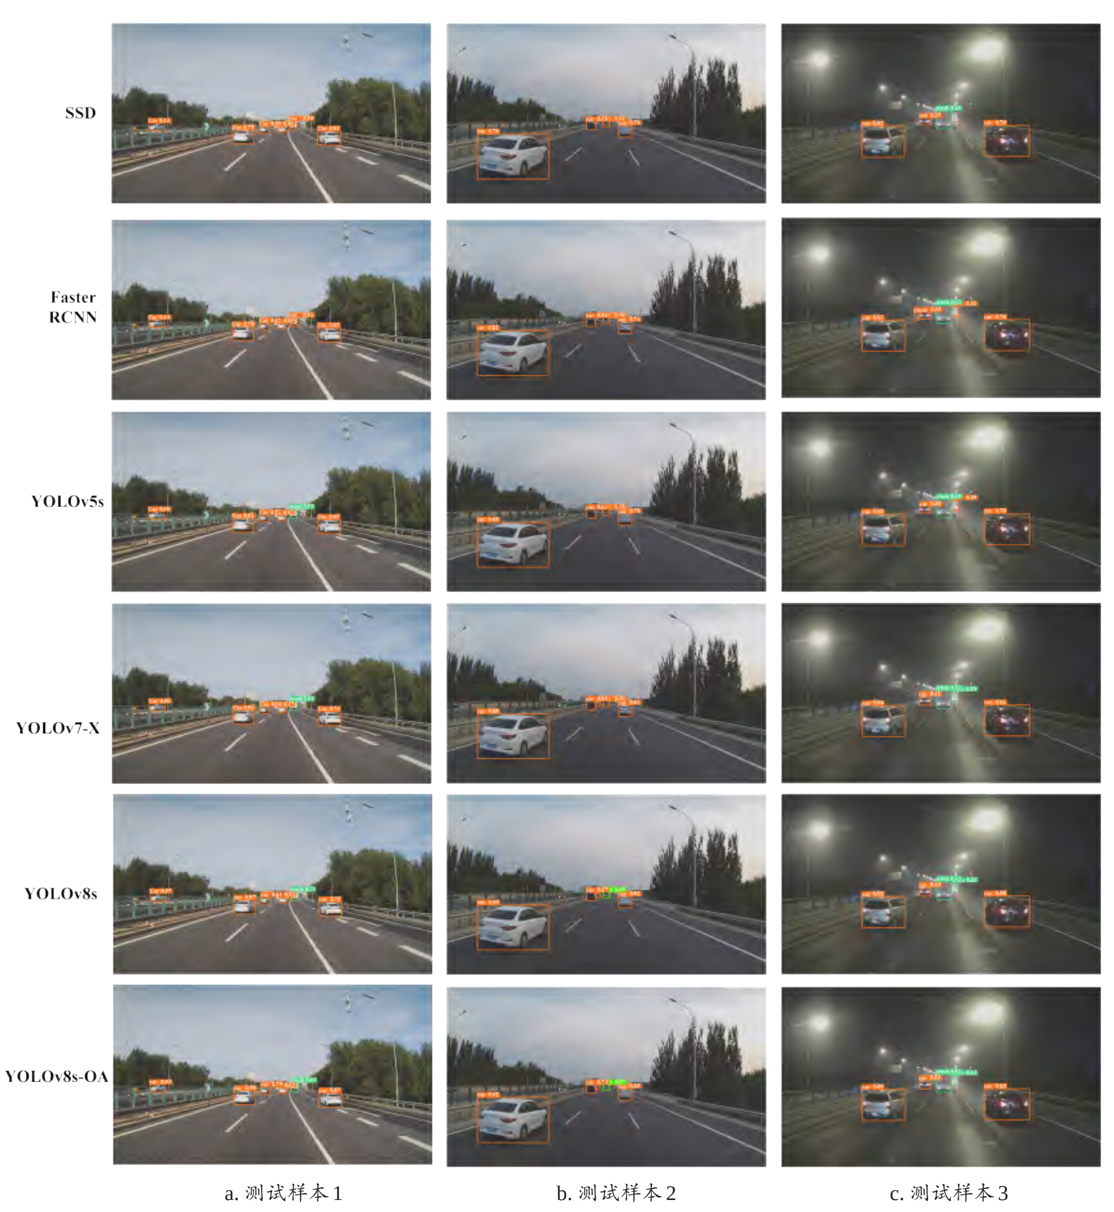
模型	精确率/%	召回率/%	$mAP_{0.5}$/%	帧率/FPS	参数量/M	运算量/GFLOPS
SSD	83.5	80.1	82.4	31	15.6	24.2
Faster-RCNN	90.1	85.8	88.1	19	42.5	118.6
YOLOv5s	93.2	89.1	93.9	32	9.2	24.0
YOLOv7-X	95.6	91.3	96.2	11	70.9	178.3
YOLOv8s	96.9	92.1	98.2	37	11.2	28.7
YOLOv8s-OA	98.1	95.5	98.4	39	9.8	19.7

Faster-RCNN（Region with CNN features）和SSD（Single Shot MultiBox Detector）等算法进行识别性能对比，结果如表2所示。可以看出，在精确率、召回率和平均精度均值方面，YOLOv8s-OA表现最优，SSD算法识别性能最差。本研究提出的YOLOv8s-OA的精确率可以达到98.1%，分别比YOLOv8s、YOLOv7-X、YOLOv5s、Faster-RCNN和SSD高出1.2%、2.6%、5.3%、8.9%和17.5%。YOLOv8s-OA的召回率为95.5%，比上述5种对比模型分别高出3.7%、4.6%、7.2%、11.3%和19.2%。YOLOv8s-OA的$mAP_{0.5}$高达98.4%，与另外5种对比模型相比，分别高出0.2%、2.3%、4.8%、11.7%和19.4%。在参数量方面，YOLOv8s-OA有9.8 M，虽然比YOLOv5s增加了6.5%，但比YOLOv8s、YOLOv7-X、Faster-RCNN和SSD分别减少了12.5%、86.2%、76.9%和37.2%。YOLOv8s-OA的运算量最低，比5种对比模型分别减少了31.4%、89.0%、17.9%、83.4%和18.6%。在检测速度方面，YOLOv8s-OA模型的检测速度最快，比YOLOv8s提升了5.4%。综上可以得出，改进后的YOLOv8s-OA模型在识别精度、模型大小和识别速度等方面表现良好，能够满足车载视角下对路况信息识别的需求。

图7直观呈现了不同深度学习模型的路况信息识别结果，各识别模型均能准确识别出近处的车辆。在识别远处小目标车辆时，SSD、Faster-RCNN、YOLOv5s和YOLOv7出现严重的误判和漏判现象。SSD在图7a和图7b中未识别出远处的轿车，同时将货车误识别为轿车，在7c中未识别出货车；Faster-RCNN在图7a、图7b和图7c中将货车误识别为轿车，将图7c阴影部分错误识别为轿车。YOLOv5s在图7a中漏判一辆轿车，在图7b中将公交车误识别为轿车，在图7c中将货车误识别为轿车。YOLOv7-X在图7a中漏判一辆轿车，在图7b图中将公交车误识别为轿车。上述4个模型均易在小目标车辆识别情况下出现严重失误，YOLOv8s模型在图7a中未识别出远处的一辆轿车，而YOLOv8s-OA能准确识别出道路上所有车辆，在小目标和遮挡车辆识别情况下表现良好。

表3为不同模块对路况识别的消融实验结果，YOLOv8s-ODConv为仅在YOLOv8s中加入全维度动态卷积模块，YOLOv8s-AFPN为仅在YOLOv8s中引入渐近特征金字塔网络模块。在只引入一个模块的情况下，YOLOv8s-ODConv的精确率、召回率和平均识别均值分别比YOLOv8s提升了1.4%、3.0%和0.1%，参数量降低了0.27%，模型运算量减少了20.6%，图像处理速度提升了2.7%。大幅度提升了路况信息识别的准确率，这是因为通过全维度动态卷积进行跨维度特征学习，充分捕获到关键信息，提升模型特征提取能力。与YOLOv8s相比，YOLOv8s-AFPN精确率和召回率分别提升了1.0%和3.4%，mAP降低了0.2%，参数量和运算量大幅缩减，分别降低了18.8%和33.4%，图像处理速度提升了5.4%，加入AFPN结构后通过渐进式逐步融合不同等级间信息，充分保留重要特征信息，提高模型的识别精度。可以看出，引入ODConv和AFPN后的YOLOv8s-OA在召回率上分别比YOLOv8s、YOLOv8s-ODConv和YOLOv8s-AFPN提升了3.7%、0.4%和0.3%，参数量上仅比YOLOvs-AFPN增加了7.7%，比YOLOv8s、YOLOv8s-ODConv分别减少了12.5%和10.1%，总体来看，YOLOv8s-OA的路况信息识别性能最优。

表4为通过人工对行车图像中路况信息进行统计的结果，可以看出在车辆数量特征中，轿车数量变化浮动最大，在像素面积占比特征中，轿车像素



a. 测试样本1　　b. 测试样本2　　c. 测试样本3

图7 车辆视角下路况图像识别测试集试验结果

Fig.7 Experimental results of road image recognition test set in vehicle perspective

表3 路况信息识别研究不同模块的消融试验结果

Table 3 Ablation test results of different modules for road condition information recognition study

Model	精确率/%	召回率/%	$mAP_{0.5}$/%	帧/FPS	参数量/M	运算量/GFLOPS
YOLOv8s	96.9	92.1	98.2	37	11.2	28.7
YOLOv8s-ODConv	98.3	94.9	98.3	38	10.9	22.8
YOLOv8s-AFPN	97.9	95.2	98.0	39	9.1	19.1
YOLOv8s-OA	98.1	95.5	98.4	39	9.8	19.7

面积占比浮动最大，这是由于测试道路中的车辆主要以轿车为主，轿车流量较大，而公交车和货车较少。为验证不同路况下车辆碳排放预测模型的精度，将车辆数量与像素面积占比之和定义为拥堵指数，并据此设定四种路况等级，其中路况指数小于8.4为畅通等级，处于［8.4, 15.9］为轻度拥堵，处于［15.9, 28.4］为中度拥堵，而大于28.4为严重拥堵。

3.3 车辆碳排放预测模型的性能比较

为验证iTransformer-EA模型的碳排放预测性能，选择长短时记忆网络（Long Short Term Memo-

表 4　基于 YOLOv8s-OA 模型路况信息统计结果

Table 4　Statistical results of road condition information based on the YOLOv8s-OA model

特征	车辆数量			像素面积占比		
	轿车/辆	公交车/辆	货车/辆	轿车像素面积占比/%	公交车像素面积占比/%	货车像素面积占比/%
最小值	2	0	0	1.9	0	0.0
最大值	11	2	3	33.6	8.9	10.3

ry, LSTM）、门控循环单元（Gated Recurrent Unit, GRU）、时域卷积网络（Temporal Convolutional Network, TCN）、Transformer 和 iTransformer 等模型在测试集上进行比较。碳排放预测结果如图 8 所示，iTransformer-EA 预测曲线最接近真实的碳排放曲线，拟合效果最佳，其次是 iTransformer、Transformer 和 TCN，而 GRU 和 LSTM 模型波动较大，拟合曲线效果差。

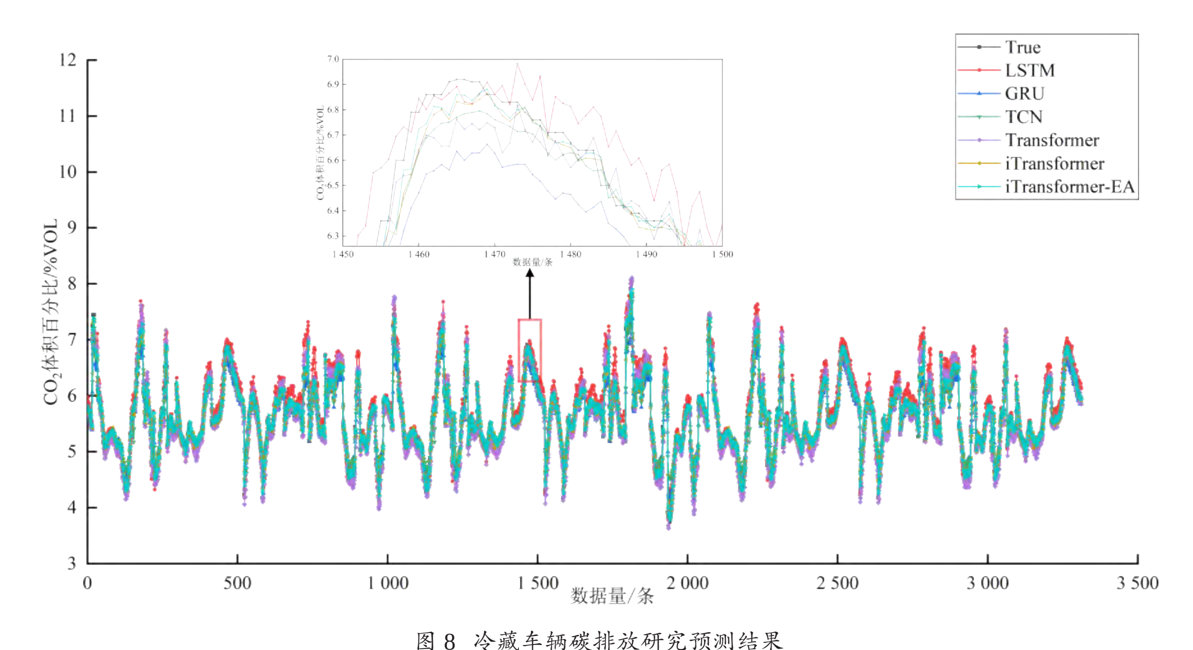


图 8　冷藏车辆碳排放研究预测结果

Fig.8　Carbon emission study projections for refrigerated vehicles

表 5 为不同模型性能评估指标结果，iTransformer-EA 的各项评价结果均优于其他对比模型，MSE、MAE、RMSE 分别为 0.026 1 %VOL、0.079 1 %VOL 和 0.161 5 %VOL，分别比 iTransformer 降低了 0.4%、15.3% 和 8.7%，R^2 达到了 0.940 0，比 iTransformer 提高了 1.3%，表明引入外部注意力可以提高 iTransformer 模型对碳排放时序数据非线性依赖关系的捕获能力，加强对重要特征的学习，提升对冷藏车辆碳排放数据的预测精度。

表 6 展示了不同路况下冷藏车辆碳排放预测模型准确性，可以看出，在畅通等级下车辆碳排放预测结果的准确性最低，其 MSE、MAE、RMSE 和 R^2 分别为 0.027 2 %VOL、0.079 6 %VOL、0.163 4 %VOL 和 0.934 1。随着道路拥堵的加剧，模型的预测精度逐步提升，相比畅通等级，严重拥堵下冷藏车辆碳排放预测精度达到最高。其 MSE、MAE、RMSE 和 R^2 分别提升了 7.7%、3.5%、2.5% 和 1.7%。这种结果主要归因于随道路拥堵等级加剧，路况信息对冷藏车辆碳排放的影响随之加强，使之更易突显路况信息及其他影响因素之间联合作用，使得冷藏车辆碳排放预测模型精度显著提升。

表 5　冷藏车辆碳排放动态预测模型评价结果

Table 5　Evaluation Results of Carbon Emission Dynamic Prediction Model for Refrigerated Vehicles

Model	MSE/ %VOL	MAE/ %VOL	RMSE/%VOL	R^2
LSTM	0.057 1	0.164 5	0.238 9	0.868 5
GRU	0.052 4	0.153 5	0.228 9	0.879 2
TCN	0.045 8	0.127 8	0.214 2	0.894 3
Transformer	0.039 2	0.130 9	0.198 0	0.909 7
iTransformer	0.030 1	0.093 4	0.176 8	0.928 0
iTransformer-EA	0.026 1	0.079 1	0.161 5	0.940 0

表 6 不同路况下冷藏车辆碳排放预测结果

Table 6 Carbon emission prediction results for refrigerated vehicles under different road conditions

路况	MSE/vol%	MAE/vol%	RMSE/vol%	R^2
畅通	0.027 2	0.079 6	0.163 4	0.934 1
轻度拥堵	0.026 9	0.078 3	0.162 0	0.938 6
中度拥堵	0.026 3	0.077 4	0.160 4	0.943 7
严重拥堵	0.025 1	0.076 8	0.159 3	0.950 1

4 结 论

本研究以城市生鲜冷链配送车辆为研究对象，基于YOLOv8s目标识别模型构建了路况信息识别模型，并以车辆行驶速度、加速度、货物重量、制冷温度、制冷功率和路况信息等多源信息为输入，构建基于iTransformer的碳排放预测模型。通过与其他模型展开对比分析，分别验证了YOLOv8s-OA路况信息识别模型和iTransformer-EA碳排放预测模型的准确性与可靠性。

首先，通过冷藏车辆碳排放影响因子相关性分析得出，行驶参数对车辆碳排放的影响最重要，其次为货物重量，路况因与行驶参数具有较强的相关性，所以对碳排放具有重要影响，虽然制冷参数对碳排放的影响较低，但均高于0.67以上，验证出所选碳排放预测模型输入参数的必要性。

然后，通过与YOLOv8s、YOLOv7、YOLOv5s、Faster-RCNN和SSD模型的对比实验得出：YOLOv8s-OA路况信息识别模型的识别精确率、召回率与平均精度均值分别高达98.1%、95.5%和98.4%，均优于对比模型。模型的参数量与运算量分别为9.8 M和19.7 GFLOPS，图像处理速度为39帧/s。在小目标车辆识别实验中，其他模型均出现不同程度的漏检和误检情况，而YOLOv8s-OA模型依然可以准确识别出小目标和受遮挡车辆，展现了显著优势，说明通过全维度动态卷积和渐进特征金字塔可以改善模型的特征提取和融合能力，保障模型对路况信息识别的准确性。

最后，通过与LSTM、GRU、TCN、Transformer与iTransformer模型进行对比可知：iTransformer-EA碳排放预测模型的预测结果与实际碳排放数据最接近，MSE、MAE、RMSE和R^2分别达到了0.026 1 %VOL、0.079 1 %VOL、0.161 5 %VOL和0.940 0，预测结果均优于对比模型，并且随着道路拥堵等级的加剧，模型预测精度逐步提升可实现冷链配送碳排放的动态精准预测。

利益冲突声明：本研究不存在研究者以及与公开研究成果有关的利益冲突。

参考文献：

[1] 王想, 邹金桂, 李由, 等. 食品冷链能效评估与碳排放核算研究综述[J]. 智慧农业(中英文), 2023, 5(1): 1-21.
WANG X, ZOU J G, LI Y, et al. Review on energy efficiency assessment and carbon emission accounting of food cold chain[J]. Smart agriculture, 2023, 5(1): 1-21.

[2] 田长青, 孔繁臣, 张海南, 等. 中国冷链碳排放及低碳技术减排分析[J]. 制冷学报, 2023, 44(4): 68-74, 111.
TIAN C Q, KONG F C, ZHANG H N, et al. Carbon emission and emission reduction with low-carbon technologies in Chinese cold chain industry[J]. Journal of refrigeration, 2023, 44(4): 68-74, 111.

[3] 赵守政, 朱宗升, 赵松松, 等. 不同供冷模式下生鲜配送碳排放计算及对比分析[J/OL]. 制冷学报, 2023: 1-11. (2023-12-01). https://kns. cnki. net/kcms/detail/11.2182. tb.20231129.1234.003.html.
ZHAO S Z, ZHU Z S, ZHAO S S, et al. Carbon emission calculation and comparative analysis during last mile fresh food distribution under different cooling modes[J/OL]. Journal of refrigeration, 2023: 1-11. (2023-12-01). https://kns. cnki. net/kcms/detail/11.2182. tb. 20231129.1234.003. html.

[4] 李军涛, 刘明月, 刘朋飞. 生鲜农产品多车型冷链物流车辆路径优化[J]. 中国农业大学学报, 2021, 26(7): 115-123.
LI J T, LIU M Y, LIU P F. Route optimization of multi-vehicle cold chain logistics for fresh agricultural products[J]. Journal of China agricultural university, 2021, 26(7): 115-123.

[5] 丁澍, 邱玉琢. 考虑低碳的多目标冷链混合车队路径规划研究[J/OL]. 计算机工程与应用, 2023: 1-13. (2023-05-18). https://kns. cnki. net/kcms/detail/11.2127. TP. 20230517.1459.013.html.
DING S, QIU Y Z. Research on route planning of multi-objective cold chain mixed fleet considering low carbon[J/OL]. Computer engineering and applications, 2023: 1-13. (2023-05-18). https://kns.cnki.net/kcms/detail/11.2127.TP.20230517.1459.013.html.

[6] JAIKUMAR R, SHIVA NAGENDRA S M, SIVANANDAN R. Modeling of real time exhaust emissions of passenger cars under heterogeneous traffic conditions[J]. Atmospheric pollution research, 2017, 8(1): 80-88.

[7] SEO J, LIM Y, HAN J, et al. Machine learning-based estimation of gaseous and particulate emissions using internally observable vehicle operating parameters[J]. Urban climate, 2023, 52: ID 101734.

[8] RIVERA-CAMPOVERDE N D, MUÑOZ-SANZ J L, DEL VALLE ARENAS-RAMIREZ B. Estimation of pollutant emissions in real driving conditions based on data from OBD and machine learning[J]. Sensors, 2021, 21(19): ID 6344.

[9] 李昌庆, 谢小平. 基于便携式排放测试系统与BP神经网络的大型客车排放预测[J]. 汽车技术, 2021(1): 57-62.
LI C Q, XIE X P. Emission prediction of large buses based on portable emission mesurement systems and BP neural network[J]. Automobile technology, 2021(1):

57-62.

[10] 曹文彬, 谢慧雯 . 考虑道路实况的冷链物流多温共配路径优化研究[J]. 物流科技, 2023, 46(15): 138-143.
CAO W B, XIE H W. Research on optimization of multi temperature co-distribution path in cold chain logistics considering road conditions[J]. Logistics sci-tech, 2023, 46(15): 138-143.

[11] AJAYI S A, ADAMS C A, DUMEDAH G, et al. The impact of traffic mobility measures on vehicle emissions for heterogeneous traffic in Lagos City[J]. Scientific African, 2023, 21: ID e01822.

[12] CHEN X, JIANG L H, XIA Y, et al. Quantifying on-road vehicle emissions during traffic congestion using updated emission factors of light-duty gasoline vehicles and real-world traffic monitoring big data[J]. The science of the total environment, 2022, 847: ID 157581.

[13] 任慧, 王东宇 . 考虑拥堵路况下碳排放的选址-配送集成优化问题[J]. 运筹与管理, 2019, 28(7): 81-90.
REN H, WANG D Y. Location-distribution integrated optimization considering carbon emissions under the congested road condition[J]. Operations research and management science, 2019, 28(7): 81-90.

[14] 常盟盟, 袁磊, 丁治明, 等 . 交通路况感知下的自适应动态路径规划方法[J]. 交通运输系统工程与信息, 2021, 21(4): 156-162, 247.
CHANG M M, YUAN L, DING Z M, et al. Adaptive dynamic path planning method under traffic condition awareness[J]. Journal of transportation systems engineering and information technology, 2021, 21(4): 156-162, 247.

[15] 史涛, 崔杰, 李松 . 优化改进YOLOv8实现实时无人机车辆检测的算法[J/OL]. 计算机工程与应用, 2024: 1-12. (2024-02-29). https://kns. cnki. net/kcms/detail/11.2127. tp.20240228.1819.031.html.
SHI T, CUI J, LI S. An algorithm for real-time vehicle detection from UAVs based on optimizing and improving YOLOv8[J/OL]. Computer engineering and applications, 2024: 1-12. (2024-02-29). https://kns.cnki.net/kcms/detail/11.2127.tp.20240228.1819.031.html.

[16] SUN S, MO B, XU J, et al. Multi-YOLOv8: An infrared moving small object detection model based on YOLOv8 for air vehicle[J]. Neurocomputing, 2024: ID 127685.

[17] 贵向泉, 刘世清, 李立, 等 . 基于改进YOLOv8的景区行人检测算法[J/OL]. 计算机工程: 1-11. [2024-03-14]. https://doi.org/10.19678/j.issn.1000-3428.0068125.
GUI X Q, LIU S Q, Li L, et al. Pedestrian detection algorithm for scenic spots based on improved YOLOv8[J/OL]. Computer Engineering and Applications: 1-11. [2024-03-14]. https://doi.org/10.19678/j.issn.1000-3428.0068125.

[18] 周飞, 郭杜杜, 王洋, 等 . 基于改进YOLOv8的交通监控车辆检测算法[J/OL]. 计算机工程与应用, 2024: 1-13. (2024-01-04). https://kns. cnki. net/kcms/detail/11.2127. TP.20240104.0953.008.html.
ZHOU F, GUO D D, WANG Y, et al. Vehicle detection algorithm based on improved YOLOv8 in traffic surveillance[J/OL]. Computer engineering and applications, 2024: 1-13. (2024-01-04). https://kns.cnki.net/kcms/detail/11.2127.TP.20240104.0953.008.html.

[19] LI C, ZHOU A J, YAO A B. Omni-dimensional dynamic convolution[EB/OL]. arXiv: 2209.07947, 2022.

[20] CHENG S X, ZHU Y S, WU S H. Deep learning based efficient ship detection from drone-captured images for maritime surveillance[J]. Ocean engineering, 2023, 285: ID 115440.

[21] YANG G Y, LEI J, ZHU Z K, et al. AFPN: Asymptotic feature pyramid network for object detection[EB/OL]. arXiv: 2306.15988, 2023.

[22] LIU S T, HUANG D, WANG Y H. Learning spatial fusion for single-shot object detection[EB/OL]. arXiv: 1911.09516, 2019.

[23] LIU Y, HU T G, ZHANG H R, et al. iTransformer: Inverted transformers are effective for time series forecasting[EB/OL]. arXiv: 2310.06625, 2023.

[24] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[C]// Proceedings of the 31st International Conference on Neural Information Processing Systems. New York, USA: ACM, 2017: 6000-6010.

[25] BRODY S, ALON U, YAHAV E. On the expressivity role of LayerNorm in transformers' attention[EB/OL]. arXiv: 2305.02582, 2023.

[26] GUO M H, LIU Z N, MU T J, et al. Beyond self-attention: External attention using two linear layers for visual tasks[J]. IEEE transactions on pattern analysis and machine intelligence, 2023, 45(5): 5436-5447.

[27] NIE H, PANG H, MA M, et al. A lightweight remote sensing small target image detection algorithm based on improved YOLOv8[J]. Sensors, 2024, 24(9): ID 2952.

[28] GUO J, DONG J, ZHOU B, et al. A hybrid model for the prediction of dissolved oxygen in seabass farming[J]. Computers and Electronics in Agriculture, 2022, 198: ID 106971.

Dynamic Prediction Method for Carbon Emissions of Cold Chain Distribution Vehicle under Multi-Source Information Fusion

YANG Lin[1,4], LIU Shuangyin[1,3], XU Longqin[1,2], HE Min[1,3], SHENG Qingfeng[1,3], HAN Jiawei[4*]

（1. *College of Information Science and Technology, Zhongkai University of Agriculture and Engineering, Guangzhou* 510225, *China*; 2. *Guangzhou Key Laboratory of Agricultural Products Quality & Safety Traceability Information Technology, Zhongkai University of Agriculture and Engineering, Guangzhou* 510225, *China*; 3. *Academy of Intelligent Agricultural Engineering Innovations, Zhongkai University of Agriculture and Engineering, Guangzhou* 510225, *China*; 4. *Research Center of Information Technology, Beijing Academy of Agriculture and Forestry Sciences, Beijing* 100097, *China*）

Abstract:

[Objective] The dynamic prediction of carbon emission from cold chain distribution is an important basis for the accurate assessment of carbon emission and its green credit grade. Facing the fact that the carbon emission of vehicles is affected by multiple factors, such as road condition information, driving characteristics, refrigeration parameters, etc., a dynamic prediction model of carbon emission was proposed from refrigerated vehicles that integrates multi-source information.

[Methods] The backbone feature extraction network, neck feature fusion network and loss function of YOLOv8s was firstly improved. The full-dimensional dynamic convolution was introduced into the backbone feature extraction network, and the multidimensional attention mechanism was introduced to capture the contextual key information to improve the model feature extraction capability. A progressive feature pyramid network was introduced into the feature extraction network, which reduced the loss of key information by fusing features layer by layer and improved the feature fusion efficiency. The road condition information recognition model based on improved YOLOv8s was constructed to characterize the road condition information in terms of the number of road vehicles and the percentage of pixel area. Pearson's correlation coefficient was used to compare and analyze the correlation between carbon emissions of refrigerated vehicles and different influencing factors, and to verify the necessity and criticality of the selection of input parameters of the carbon emission prediction model. Then the iTransformer temporal prediction model was improved, and the external attention mechanism was introduced to enhance the feature extraction ability of iTransformer model and reduce the computational complexity. The dynamic prediction model of carbon emission of refrigerated vehicles based on the improved iTransformer was constructed by taking the road condition information, driving characteristics (speed, acceleration), cargo weight, and refrigeration parameters (temperature, power) as inputs. Finally, the model was compared and analyzed with other models to verify the robustness of the road condition information and the prediction accuracy of the vehicle carbon emission dynamic prediction model, respectively.

[Results and Discussions] The results of correlation analysis showed that the vehicle driving parameters were the main factor affecting the intensity of vehicle carbon emissions, with a correlation of 0.841. The second factor was cargo weight, with a correlation of 0.807, which had a strong positive correlation. Compared with the vehicle refrigeration parameters, the road condition information had a stronger correlation between vehicle carbon emissions, the correlation between refrigeration parameters and the vehicle carbon emissions impact factor were above 0.67. In order to further ensure the accuracy of the vehicle carbon emissions prediction model, The paper was selected as the input parameters for the carbon emissions prediction model. The improved YOLOv8s road information recognition model achieved 98.1%, 95.5%, and 98.4% in precision, recall, and average recognition accuracy, which were 1.2%, 3.7%, and 0.2% higher than YOLOv8s, respectively, with the number of parameters and the amount of computation being reduced by 12.5% and 31.4%, and the speed of detection being increased by 5.4%. This was due to the cross-dimensional feature learning through full-dimensional dynamic convolution, which fully captured the key information and improved the feature extraction capability of the model, and through the progressive feature pyramid network after fusing the information between different classes through gradual step-by-step fusion, which fully retained the important feature information and improved the recognition accuracy of the model. The predictive performance of the improved iTransformer carbon emission prediction model was better than other time series prediction models, and its prediction curve was closest to the real carbon emission curve with the best fitting effect. The introduction of the external attention mechanism significantly improved the prediction accuracy, and its MSE, MAE, RMSE and R^2 were 0.026 1 %VOL, 0.079 1 %VOL, 0.161 5 %VOL and 0.940 0, respectively, which were 0.4%, 15.3%, 8.7% and 1.3% lower, respectively, when compared with iTransformer. As the degree of road congestion increased, the prediction accuracy of the constructed carbon emission prediction model increased.

[Conclusions] The carbon emission prediction model for cold chain distribution under multi-source information fusion proposed in this study can realize accurate prediction of carbon emission from refrigerated vehicles, provide theoretical basis for rationally formulating carbon emission reduction strategies and promoting the development of low-carbon cold chain distribution.

Key words: cold chain distribution; carbon emissions; road condition recognition; time series prediction; YOLOv8s; iTransformer; Multi-Source Information Fusion; AFPN

Foundation items: National Natural Science Foundation projects (62373390, 61871475); National Key R&D Program projects (2022YFD2001804, 2023YFD2001302); Beijing Academy of Agriculture and Forestry Sciences Research Innovation Platform Construction Project (PT2024-24)

Biography: YANG Lin, E-mail: yanglinear@163.com

***Corresponding author:** HAN Jiawei, E-mail: hanjw@nercita.org.cn

(登录www.smartag.net.cn免费获取电子版全文)